



Imagens de Raios X e YOLOv8 para Avaliação Automatizada, Precisa e Não Destrutiva da Qualidade de Sementes Braquiária (*Urochloa brizantha*)

**Rafael Capelo Domingues¹, Gabriel Vasconcelos Fruet¹,
Haynna Fernandes Abud², Danielo G. Gomes¹**

¹Grupo de Redes de Computadores, Engenharia de Software e Sistemas (GREat)
Departamento de Engenharia de Teleinformática
Centro de Tecnologia, Universidade Federal do Ceará (UFC), Fortaleza - CE

²Image Pesquisas Sementes e Plantas
Parque de Desenvolvimento Tecnológico – PADETEC/UFC, Fortaleza-CE

[rafaelcapelo22, gabrielfruet]@alu.ufc.br

haynna@imagepesquisas.com.br, danielo@ufc.br

Abstract. *Seed quality is crucial in agriculture. Companies that produce seeds are concerned about finding rapid tests that accurately assess seed vigor, and the time it takes to conduct these tests is a limiting factor. Here we apply the YOLOv8 model to quickly, automatically, and non-destructively evaluate the physiological potential of seeds. The proposed method uses radiographic images of brachiaria seeds (*Urochloa brizantha*) to identify and classify them based on their physiological quality. The YOLOv8 network was trained with a dataset of seed images, and the results demonstrated high accuracy in identifying and classifying the seeds, with mAP50 and mAP50-95 metrics of 90.6% and 90.1%, respectively, for all classes.*

Resumo. *A qualidade das sementes é essencial na agricultura. A busca por testes rápidos para aferir com acurácia o vigor das sementes é uma preocupação de empresas produtoras, para as quais o tempo de execução dos testes é um fator limitante. Este artigo aplica a arquitetura YOLOv8 para avaliar a qualidade de sementes de forma rápida, automatizada e não destrutiva. O método proposto utiliza imagens radiográficas de sementes braquiárias (*Urochloa brizantha*) para identificar e classificá-las com base em sua qualidade fisiológica. A rede YOLOv8 foi treinada com um conjunto de dados de imagens de sementes e os resultados mostraram uma alta precisão na identificação e classificação das mesmas, com métricas mAP50 e mAP50-95, respectivamente, 90.6% e 90.1% em relação a todas as classes.*

1. Introdução

As forrageiras tropicais representam um dos alimentos mais importantes na produção animal em todo o mundo. Para obtenção de uma alta população de plantas em campo, com desenvolvimento uniforme, é essencial que sejam utilizadas sementes de alta qualidade visando, com isso, alcançar o máximo potencial produtivo de uma cultura [Abud et al. 2018]. A busca por testes rápidos que gerem resultados representativos da qualidade das sementes é uma constante preocupação de empresas produtoras, para as quais o tempo de execução dos testes é um fator limitante. Nota-se portanto uma demanda emergente de métodos automatizados que permitam avaliar, com agilidade e eficiência, a qualidade fisiológica de sementes.

A eficiência de técnicas de análise de imagens tem sido abordada na literatura recente, cujos trabalhos correlacionam parâmetros obtidos por imagens a padrões de qualidade das sementes [Sudki et al. 2023, de Freitas et al. 2021, Abud et al. 2018]. O teste de raios X, por exemplo, é um método rápido e não destrutivo recomendado pelas Regras para a Análise de Sementes¹ e regras internacionais prescritas pela *International Seed Testing Association* – ISTA².

Neste contexto, sementes do gênero *Urochloa* tem sido objeto de estudos recentes com processamento de imagens, através do qual dados biométricos das sementes são relacionados a suas informações fisiológicas, e.g. porcentagem de germinação, velocidade de emergência [Ramos et al. 2022, de Freitas et al. 2021]. Em particular, imagens de raios X de *Urochloa brizantha* tem sido utilizadas para verificar a ocorrência de danos nas sementes durante seu beneficiamento [Silva et al. 2022, Jeromini et al. 2019].

O objetivo deste artigo é a automatização de métodos de análise de imagens de raios X, por meio de técnicas de aprendizado de máquina, de sementes de braquiária (*Urochloa brizantha* cv. *Xaraés*) para obter parâmetros de qualidade de lotes de sementes em função da sua morfologia interna. Deste modo, buscamos uma estimativa rápida, precisa e não destrutiva sobre o vigor e a qualidade dessas sementes.

2. Material e Método

Nesta seção, descrevemos todo o processo metodológico da formação do banco de imagens e o treinamento do modelo de visão computacional para detecção e classificação adotado.

2.1. Objeto de Estudo

A braquiária (*Urochloa brizantha* cv. *Xaraés*) é uma das forrageiras tropicais mais amplamente cultivadas no mundo, tornando a avaliação automática da qualidade de suas sementes de grande interesse para a indústria agrícola. Neste estudo, utilizamos lotes de sementes de braquiária selecionadas posteriormente em amostras aleatórias para a captura das imagens radiográficas. A Figura 1 enfatiza o pequeno porte das sementes objeto deste estudo, cujo pequeno porte é um forte apelo para a avaliação automatizada por imagens.

¹https://www.gov.br/agricultura/pt-br/assuntos/insumos-agropecuarios/arquivos-publicacoes-insumos/2946_regras_analise_sementes.pdf

²Chapter 14: The X-ray test, doi:10.15258/istarules.2023.14



Figura 1. Amostra real de sementes de braquiária (*Urochloa brizantha*).

2.2. Captura das Imagens de Raio-X

Para obtenção das imagens radiográficas, foram realizadas dez repetições de 20 sementes para cada lote. As sementes foram distribuídas em folhas de plástico transparente, utilizando-se fita adesiva dupla face para fixação das sementes na posição desejada, em que a visualização das suas partes, como embrião, endosperma e tegumento, além dos espaços vazios, pudessem ser facilmente visualizados (Figura 2).

Nota-se ainda na Figura 2 que as imagens de raios X das sementes apresentam diferenças no tocante à morfologia interna, tais como baixa qualidade (#5 #15 #19), má formação (#4 e #11) e presença de danos no embrião (#17). Essas características têm grande impacto na qualidade do lote de sementes, afetando diretamente a germinação e o vigor das plantas.




Figura 2. Imagens radiográficas de sementes de *Urochloa brizantha*, cv. Xaráes.

As imagens radiográficas foram realizadas com equipamento digital Faxitron, modelo MX 20 DC-12, acoplado a um computador Core 2 Duo (3.16 GHz, 2 GB de memória

RAM, disco rígido de 160 GB) e monitor MultiSync (LCD1190SX de 17 polegadas) e submetidas à radiação por 20 segundos a 20 kV. Todas as imagens foram gravadas em um dispositivo externo e utilizadas posteriormente (processamento em lote).

2.3. Detecção e Classificação das Sementes

Para realizar a tarefa de detecção e classificação das sementes, optamos por uma abordagem de treinamento supervisionado, utilizando a plataforma **Roboflow**³ para o tratamento dos dados em função de seus recursos avançados de rotulagem e de geração de dados sintéticos (*augmentation*) de imagens. Rotulamos as 20 sementes de cada imagem em quatro categorias (Figura 3): "Alta Qualidade"(Delimitadas em verde), "Intermediária"(Delimitadas em roxo), "Baixa Qualidade"(Delimitadas em laranja) e "Inviável"(Delimitadas em Vermelho), localizando e classificando-as via caixas delimitadoras (*bouding boxes*) representadas por tuplas com os parâmetros do centro de cada semente bem como altura e comprimento da respectiva caixa delimitadora.

O processo de rotulagem foi realizado com base em critérios específicos para cada categoria, como a presença de danos, deformações no endosperma ou má formação das sementes. A plataforma Roboflow permitiu executar iterações rápidas e ajustar os rótulos facilitando o estágio de treinamento.




Figura 3. Imagem exemplo de processo manual de delimitação e classificação.

2.4. YOLOv8

O modelo convolucional YOLOv8 [Jocher et al. 2023] é um dos mais avançados no campo de detecção de objetos, segmentação de instâncias e classificação de imagens em estágio único. É aprimorado a partir de arquiteturas anteriores da família YOLO [Bochkovskiy et al. 2020], alcançando desempenho superior ao utilizar o banco de imagens COCO [Lin et al. 2014] para treinamento e inferência. Este modelo é baseado na arquitetura da família YOLO com algumas melhorias. Em particular, o modelo YOLOv8x, com 68.127.420 parâmetros, foi selecionado para esta pesquisa devido à sua robustez.

³<https://roboflow.com/>

Optamos pelo modelo YOLOv8 em detrimento de outros devido à sua praticidade de treinamento e acurácia. Esta escolha foi justificada pela técnica de transferência de aprendizado, onde aproveitamos os pesos da rede previamente treinada no banco de imagens COCO. Em outras linhas de pesquisa, por exemplo, utilizamos outros modelos de detecção tal qual **Detectron2**⁴ como processo intermediário de avaliação e não obtivemos resultados tão precisos quanto os deste artigo.

O modelo foi treinado com o banco aumentado de imagens das sementes, dividido aleatoriamente em uma proporção de 70% e 30% para treinamento e validação, respectivamente. Além disso, utilizamos a técnica de validação cruzada, particionando o banco de imagens em cinco conjuntos distintos. Em cada iteração, treinamos o modelo em quatro desses conjuntos e validamos no conjunto restante, garantindo uma avaliação mais robusta e abrangente do desempenho do modelo. Adotamos uma implementação do modelo criado pela Ultralytics⁵ a qual inclui mecanismos de prevenção contra *overfitting*, como a técnica de *dropout*, a qual inativa alguns neurônios para equilibrar os pesos da rede, a parada antecipada em caso de falta de progresso (definida em 50 épocas de treinamento) e a transferência de pesos do treinamento com o banco de imagens COCO. O modelo foi treinado em diferentes épocas (100, 200 e 300) com valores padrões dos hiperparâmetros⁶ da implementação para taxa de aprendizado, *momentum*, dentre outros.

2.5. Google Colab

Para treinar o modelo, utilizamos o ambiente virtual do *Google Colab*, o qual fornece recursos computacionais como CPU, GPU e memória de maneira gratuita. O uso da GPU Tesla T4, com 15360 MB de memória e a versão CUDA 12.0, permitiu uma execução mais rápida e eficiente dos códigos de treinamento do modelo adotado. A utilização da GPU resultou em um tempo de treinamento de aproximadamente 45 min para o banco aumentado de imagens adotado.

3. Resultados e Discussão

Após o treinamento do modelo YOLOv8, obtivemos resultados animadores em relação à velocidade de inferência (82.7 ms) e precisão na detecção e classificação das imagens de sementes (Figura 4).

As métricas mAP50 e mAP50-95 são importantes métricas de acurácia para modelos de detecção de objetos em imagens. O termo *mAP* significa *mean average precision*, ou seja, é uma medida da média da precisão em relação a várias classes. A métrica mAP50 considera uma detecção correta se a sobreposição entre a caixa delimitadora prevista pelo modelo e a caixa delimitadora real da imagem de referência é maior que 50%, enquanto a mAP50-95 considera uma detecção correta se a sobreposição é maior que 50% até 95%. Quanto mais próximas de 100% essas métricas, mais acurado o modelo.

Neste artigo, as métricas mAP50 e mAP50-95 próximas de 90% para todas as classes (Tabela 1) indicam que o modelo utilizado apresentou alta acurácia na detecção e classificação de sementes de braquiárias. Além disso, foi observada elevada precisão das caixas delimitadoras e na classificação específica de sementes inviáveis, com um tempo

⁴<https://github.com/facebookresearch/detectron2>

⁵<https://github.com/ultralytics/ultralytics>

⁶<https://docs.ultralytics.com/usage/cfg/train>



Figura 4. Inferência do melhor modelo em uma imagem de validação (tempo de execução de 82.7 ms.)

médio de inferência na ordem de milissegundos, levando em consideração o hardware mencionado na Seção 2 (Material e Método). Com uma detecção precisa, é possível reduzir a ocorrência de falsos positivos e falsos negativos, o que aumenta a confiabilidade da proposta. Esses resultados validam a eficácia do modelo YOLOv8 para a detecção e classificação de sementes de braquiária, levando em conta a quantidade reduzida de amostras de treinamento em comparação a uma abordagem supervisionada comum mais robusta.

Tabela 1. Resultados das métricas de avaliação do melhor treinamento.

Classe	Instâncias	mAP50	mAP50-95
Alta Qualidade	92	0,836	0,834
Intermediária	76	0,814	0,811
Baixa Qualidade	14	0,978	0,964
Inviável	18	0,995	0,995
Todas	200	0,906	0,901

Uma análise mais detalhada dos gráficos de desempenho (Figura 5) revela que o processo de treinamento sugere uma convergência nas métricas de precisão e erro. Na Figura 5 temos de cima para baixo e da esquerda para a direita as métricas: erro da caixa delimitadora durante o treinamento, erro de classificação durante o treinamento, erro focal distributivo durante o treinamento, métrica de precisão, métrica de *recall*, erro da caixa delimitadora durante a validação, erro de classificação durante a validação, erro focal distributivo durante a validação, métrica mAP50 e métrica mAP50-95. Notar que todas as curvas de erro convergem para mínimos e todas as métricas de precisão convergem para máximos. Apesar das oscilações nas curvas poderem indicar demanda de ajuste fino nos hiperparâmetros (e.g. taxa de aprendizado) percebemos, pela ausência de *overfitting*, que o modelo YOLOv8 conseguiu generalizar.

Nossa proposta é automatizada e precisa para a avaliação da qualidade de semen-

tes em comparação com os métodos tradicionais de avaliação, como o processamento digital das imagens através de múltiplos filtros e a seleção e classificação manual via software.

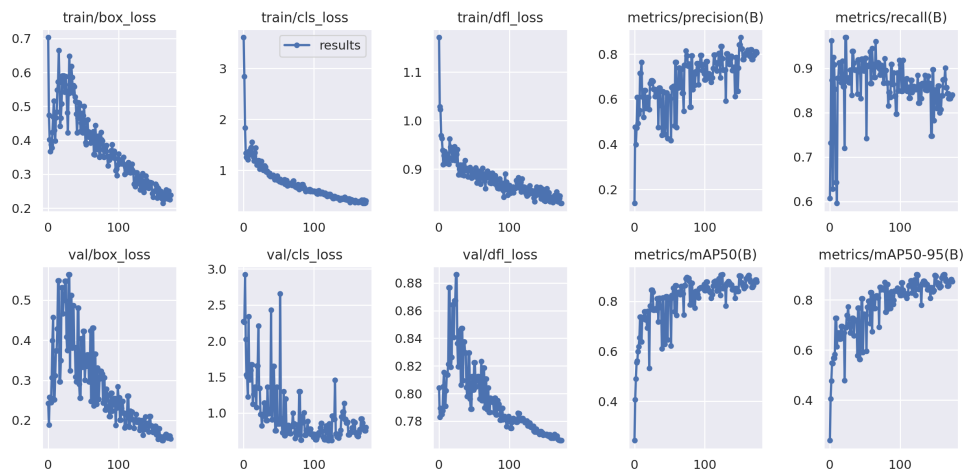


Figura 5. Métricas de desempenho de treinamento do modelo YOLOv8.

4. Conclusão

Neste artigo, propomos a aplicação do modelo YOLOv8 para a detecção e classificação de sementes a partir de imagens de raio X na qualidade de uma alternativa promissora e precisa para avaliar o vigor das sementes de forma automatizada. A partir dos bons resultados com as braquiárias da espécie *Urochloa brizantha cv. Xaraés*, sugerimos fortemente a extensão da nossa proposta para outras espécies de sementes. Uma oportunidade de sequência deste trabalho é otimizar os hiperparâmetros na fase de treinamento, o que seguramente propiciará melhor acurácia na detecção e classificação das sementes.

Agradecimentos

O presente artigo foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Danielo G. Gomes agradece o suporte financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) através dos processos 432585/2016-8 e 310317/2019-3. Rafael Capelo e Gabriel Fruet também agradecem ao CNPq pelas bolsas PIBIC (processos 136984/2023-1 e 136961/2023-1, respectivamente).

Referências

- Abud, H. F., Cicero, S. M., and Gomes Junior, F. G. (2018). Radiographic images and relationship of the internal morphology and physiological potential of broccoli seeds. *Acta Scientiarum Agronomy*, 40(Acta Sci., Agron., 2018 40):e34950.
- Bochkovskiy, A., Wang, C., and Liao, H. M. (2020). Yolov4: Optimal speed and accuracy of object detection. *CoRR*, abs/2004.10934.
- de Freitas, M. N., Dias, M. A. N., Gomes-Junior, F. G., Abud, H. F., de Araújo, L. B., and de Moraes, T. F. (2021). Discrimination of urochloa seed genotypes through image analysis: Morphological features. *Agronomy Journal*, 113(6):4930–4944.
- Jeromini, T. S., Martins, C. C., Pereira, F. E. C. B., and Gomes, F. G. (2019). The use of x-ray to evaluate brachiaria brizantha seeds quality during seed processing. *Revista Ciência Agronômica*, 50(Rev. Ciênc. Agron., 2019 50(3)):439–446.
- Jocher, G., Chaurasia, A., and Qiu, J. (2023). YOLO by Ultralytics.
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., and Zitnick, C. L. (2014). Microsoft coco: Common objects in context. In Fleet, D., Pajdla, T., Schiele, B., and Tuytelaars, T., editors, *Computer Vision – ECCV 2014*, pages 740–755, Cham. Springer International Publishing.
- Ramos, A. K. F., Medeiros, A. D. d., Pereira, M. D., Araújo, Y. F., Silva, L. J. d., and Alves, C. Z. (2022). Sars software for analysis of radiographic images of urochloa decumbens (stapf) rd webster seeds. *Journal of Seed Science*, 44:e202244045.
- Silva, A., de Oliveira, L., Pereira da Silva, C., Tiago, C., Mendes, E., Ferreira, A., Safadi, T., and Carvalho, M. (2022). Seed quality of brachiaria brizantha by x-ray image analysis using a bayesian approach. *Acta Scientiarum Agronomy*, 44:2022.
- Sudki, J. M., Fonseca de Oliveira, G. R., de Medeiros, A. D., Mastrangelo, T., Arthur, V., Amaral da Silva, E. A., and Mastrangelo, C. B. (2023). Fungal identification in peanuts seeds through multispectral images: Technological advances to enhance sanitary quality. *Frontiers in Plant Science*, 14.